JC921 U.S. PTO
09/748542
12/26/00

日本国特許庁
PATENT OFFICE
JAPANESE GOVERNMENT

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。
This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日
Date of Application: １９９９年１２月２７日

出願番号
Application Number: 平成１１年特許願第３７０４１３号

出願人
Applicant (s): インターナショナル・ビジネス・マシーンズ・コーポレイション

CERTIFIED COPY OF
PRIORITY DOCUMENT

２０００年 ３月１０日

特許庁長官
Commissioner,
Patent Office 近藤隆彦

出証番号 出証特２０００－３０１４４７０

0

【書類名】　特許願

【整理番号】　JA999251

【あて先】　特許庁長官　殿

【国際特許分類】　G06F 17/00

【発明者】

【住所又は居所】　神奈川県大和市下鶴間１６２３番地１４　日本アイ・ビー・エム株式会社　東京基礎研究所内

【氏名】　伊東　信泰

【発明者】

【住所又は居所】　神奈川県大和市下鶴間１６２３番地１４　日本アイ・ビー・エム株式会社　東京基礎研究所内

【氏名】　西村　雅史

【特許出願人】

【識別番号】　390009531

【住所又は居所】　アメリカ合衆国１０５０４、ニューヨーク州アーモンク（番地なし）

【氏名又は名称】　インターナショナル・ビジネス・マシーンズ・コーポレイション

【代理人】

【識別番号】　100086243

【弁理士】

【氏名又は名称】　坂口　博

【選任した代理人】

【識別番号】　100091568

【弁理士】

【氏名又は名称】　市位　嘉宏

【手数料の表示】

【予納台帳番号】　024154

【納付金額】　21,000円

【提出物件の目録】

【物件名】　明細書　1

【物件名】　図面　1

【物件名】　要約書　1

【包括委任状番号】　9706050

【包括委任状番号】　9704733

【プルーフの要否】　要

【書類名】　明細書

【発明の名称】音声認識装置、方法、コンピュータ・システム及び記憶媒体

【特許請求の範囲】

【請求項１】

アナログ音声入力信号をデジタル信号に変換処理を行う音響処理手段と、

音の特徴を学習した音響モデルを記憶した記憶手段と、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶手段と、

前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する手段と、

を有する音声認識装置。

【請求項２】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項１記載の音声認識装置。

【請求項３】

アナログ音声の入力手段と、

前記アナログ音声をデジタル信号に変換処理する手段と、

音の特徴を学習した音響モデルを記憶した記憶手段と、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶手段と、

前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する手段と、

前記認識された結果を表示する表示装置と

を有するコンピュータ・システム。

【請求項４】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項３記載の音コンピュータ・システム。

【請求項５】

アナログ音声入力信号をデジタル信号に変換処理し、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶し、

前記デジタル信号について音響モデルと前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する音声認識方法。

【請求項６】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項５記載の音声認識方法。

【請求項７】

アナログ音声を入力し、

前記アナログ音声をデジタル信号に変換処理し、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶し、

前記デジタル信号について音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識し、

前記認識された結果を表示する音声認識方法。

【請求項８】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項７記載の音声認識方法。

【請求項９】

コンピュータ・プログラムを有するコンピュータ読みとり可能な記憶媒体であって、前記記憶媒体は、

音響モデルと、

冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習し

た第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書

を記憶し、さらに前記コンピュータ・プログラムは、コンピュータに入力されたアナログ音声入力信号が変換されたデジタル信号について前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させるものである記憶媒体。

【請求項１０】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項９記載の記憶媒体。

【請求項１１】

冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶媒体。

【請求項１２】

前記第１及び第２の言語モデルはＮ－ｇｒａｍモデルである請求項１１記載の記憶媒体。

【請求項１３】

冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識をするための装置であって、

（１）認識の対象となる入力された語が通常単語かどうか判断する手段と、

（２）前記（１）で通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断する手段と、

（３）前記（２）で条件となる語が通常単語のみでなく冗長語も含むと判断された場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させる手段と、

を有する音声認識装置。

【請求項１４】

前記装置はさらに、

（１－１）前記（１）で、対象となる語が通常単語でないと判断された場合、第１の言語モデルに基づいて確率を計算する手段を有する請求項１３記載の音声認識装置。

【請求項１５】

前記装置はさらに、

（２－１）前記（２）で条件となる語が通常単語のみからなると判断された場合、第２の言語モデルに基づいて確率を計算する手段を有する請求項１３又は１４記載の音声認識装置。

【請求項１６】

前記（３）はさらに、

（３－１）対象となる語の直前が冗長語かどうかを判断する手段と、

（３－２）前記（３－１）で、直前が冗長語であると判断された場合、第１の言語モデルと第２の言語モデルから確率を計算する手段と、

を有する請求項１３ないし１５のいずれか記載の音声認識装置。

【請求項１７】

前記装置はさらに、

（３－１－２）前記（３－１）で、直前の語が冗長語でないと判断された場合、第２のモデルから確率を計算する手段を有する請求項１３ないし１６のいずれか記載の音声認識装置。

【請求項１８】

冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識をするための方法であって、

（１）認識の対象となる入力された語が通常単語かどうか判断するステップと、

（２）前記ステップ（１）で通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断するステップと、

（３）前記ステップ（２）で条件となる語が通常単語のみでなく冗長語も含むと

判断された場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させるステップと、

を有する音声認識方法。

【請求項１９】

前記方法はさらに、

（１－１）前記ステップ（１）で、対象となる語が通常単語でないと判断された場合、第１の言語モデルに基づいて確率を計算するステップを有する請求項１８記載の音声認識方法。

【請求項２０】

前記方法はさらに、

（２－１）前記ステップ（２）で条件となる語が通常単語のみからなると判断された場合、第２の言語モデルに基づいて確率を計算するステップを有する請求項１８または１９記載の音声認識方法。

【請求項２１】

前記ステップ（３）はさらに、

（３－１）対象となる語の直前が冗長語かどうかを判断するステップと、

（３－２）前記ステップ（３－１）で、直前が冗長語であると判断された場合、第１の言語モデルと第２の言語モデルから確率を計算するステップと、

を有する請求項１８ないし２０のいずれか記載の音声認識方法。

【請求項２２】

前記方法はさらに、

（３－１－２）前記ステップ（３－１）で、直前の語が冗長語でないと判断された場合、第２のモデルから確率を計算するステップを有する請求項１８ないし２１のいずれか記載の音声認識方法。

【請求項２３】

冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識

をするためのコンピュータ・プログラムを有するコンピュータ読みとり可能な記憶媒体であって、前記コンピュータ・プログラムは、コンピュータに

（１）認識の対象となる入力された語が通常単語かどうか判断する手順と、

（２）前記手順（１）で通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断する手順と、

（３）前記手順（２）で条件となる語が通常単語のみでなく冗長語も含むと判断された場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させる手順と、

を実行させるものである記憶媒体。

【請求項２４】

前記プログラムはさらにコンピュータに、

（１－１）前記手順（１）で、対象となる語が通常単語でないと判断された場合、第１の言語モデルに基づいて確率を計算する手順を実行させるものである請求項２３記載の記憶媒体。

【請求項２５】

前記プログラムはさらにコンピュータに、、

（２－１）前記手順（２）で条件となる語が通常単語のみからなると判断された場合、第２の言語モデルに基づいて確率を計算する手順を実行させるものである請求項２３または２４記載の記憶媒体。

【請求項２６】

前記プログラムはさらにコンピュータに、、

（３－１）対象となる語の直前が冗長語かどうかを判断する手順と、

（３－２）前記手順（３－１）で、直前が冗長語であると判断された場合、第１の言語モデルと第２の言語モデルから確率を計算する手順と、

を実行させるものである請求項２３ないし２５のいずれか記載の記憶媒体。

【請求項２７】

前記プログラムはさらにコンピュータに、

（３－１－２）前記手順（３－１）で、直前の語が冗長語でないと判断された場合、第２のモデルから確率を計算する手順を実行させるものである請求項２３ないし２６のいずれか記載の記憶媒体。

【請求項２８】

アナログ音声入力信号をデジタル信号に変換処理を行う音響処理装置と、

音の特徴を学習した音響モデルを記憶した第１の記憶装置と、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した第２の記憶装置と、

前記音響処理装置及び前記第１及び第２の記憶装置に接続され、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する装置と、

を有する音声認識装置。

【請求項２９】

アナログ音声の入力装置と、

前記入力装置に接続され、前記アナログ音声をデジタル信号に変換処理する変換装置と、

音の特徴を学習した音響モデルを記憶した第１の記憶装置と、

予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した第２の記憶装置と、

前記変換装置及び前記第１及び第２の記憶装置に接続され、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する装置と、

前記認識された結果を表示する表示装置と

を有するコンピュータ・システム。

【発明の詳細な説明】

【０００１】

【産業上の利用分野】

本発明は、音声認識装置およびその方法に関するものであり、より具体的には、人の自然な発話を認識して文章化し、冗長語（disfluency）と呼ばれる無意味な単語を自動的に除去してテキストデータを作成する音声認識装置およびその方法に関するものである。

【０００２】

【従来の技術】

音響モデルと言語モデルを用いて音声認識を行う統計的方法は知られており、例えば、「A Maximum Likelihood Approach to Continuous Speech Recognition（L.R. Bahl他, IEEE Trans. Vol. PAMI-5, No. 2, 1983, March）」や「単語を認識単位とした日本語の大語彙連続音認識（西村他、情報処理学会論文誌、第４０巻、第４号、１９９９年４月）」がそのような方法について記述している。その概略について説明すると、生成された文章Wが発話され、それが音響処理部において音響処理されて得られた信号からその特徴Xが抽出され、そのX及びWを用いて、以下の式

【数１】

$$W' = \underset{W}{argmax}\, P(W|X) = \underset{W}{argmax}\, P(W)P(X|W)$$

言語モデル　　音響モデル

に従って最適と考えられる認識結果W’が出力され、文章が構成される。つまり、単語列Wが発声されたときの当該特徴量（X）の出現確率Ｐ（Ｘ｜Ｗ）とW自身の出現確率（Ｐ（Ｗ））の積が最大（ａｒｇｍａｘ）となる単語列W’が認識結果として選択される。

【０００３】

ここで前者の確率Ｐ（Ｘ｜Ｗ）を求めるために音響モデルが用いられ、その確

率の高い単語が認識の候補として選択される。一方、後者の確率Ｐ（Ｗ）を近似するためによく用いられるものが言語モデルであり、具体的にはＮ－ｇｒａｍモデルである。これはＮ個の連続した単語組の出現確率から文全体、すなわち単語列Ｗの出現確率を近似する方法であり、次式のように定式化される。

【数２】

$$P(W) = P(w_0)P(w_1|w_0)P(w_2|w_0w_1)\times \cdots, P(w_n|w_0w_1,\cdots,w_{n-1})$$
$$\cong P(w_0)P(w_1|w_0)\prod_{i=2}^{n} P(w_i|w_{i-2}w_{i-1})$$

【０００４】

かかる式では、次の単語w[n]の出現確率が直前のＮ－１個の単語にのみ影響を受けるという仮定を行う。Ｎの値はさまざまなものが考えられるが、その有効性と必要とする学習データのバランスからＮ＝３がよく用いられ、本式もＮ＝３の場合を記述している。以下、ｎ個の語からなる文章Ｗのｎ番目の語をw[n]のように表現することとすると、ここでは当該Ｎ－１個（つまり２個）という条件の元での単語w[n]の出現確率、つまりP(w[n]|w[n-2]w[n-1])の積として単語列Ｗの出現確率が計算される。ここで、かかる式において、|の左（W[n]）は認識の対象となる単語を示し、|の右（w[n-2]w[n-1]）はその条件となる２つ前、１つ前の単語を示す。さまざまな単語w[n]についてのそれぞれの出現確率P(w[n]|w[n-2]w[n-1])はあらかじめ用意されたテキストデータより学習しておき、辞書としてデータベース化して保存しておく。例えば、文の先頭に「単語」という語が出現する確率は0.0021、その後に「検索」が続く確率は0.001等のようにして保存されている。

【０００５】

さて、あらかじめ用意された原稿があるような場合については、上述したＮ－ｇｒａｍモデルで十分であるが、音声認識の適用分野でそのような場合はむしろまれであり、実際はより自然な発話を認識することが応用上重要である。その場合には、内容・意味をもつ通常の単語だけではなく、「アノー」「ソノー」とい

った間投詞的表現や「エー」「アー」といった無意味な単語が発声される。これらは不要語や冗長語と呼ばれるが、それらに対応したＮ－ｇｒａｍモデルを作成し、それらが自動的に除去されることが望ましい。

【０００６】

従来、このために提案されたＮ－ｇｒａｍモデルの拡張は「透過単語」という概念を導入したものであった。たとえば「単語Ｎ－ｇｒａｍモデルを用いた音声認識システムにおける未知語・冗長語の処理（甲斐他、情報処理学会論文誌、第４０巻、４号、１９９９年４月）」や「放送音声の書き起こしに関する検討（西村、伊東、音響学会秋季全国大会、１９９８年）」にはその方法が記述されている。たとえば前者では「冗長語は文節間において比較的自由に出現するものであり、連接制約であるＮ－ｇｒａｍが有効に働くとは考えられない」という仮定を元に学習時、認識時いずれにおいても、冗長語の存在を無視して確率計算が行なわれる。たとえば、w[n-1]を冗長語だとするとw[n]の出現確率は

P(w[n]|w[n-2]w[n-1])

から計算されるべきところを、w[n-1]を無視し、P(w[n]|w[n-3]w[n-2])として推定する。このように無視される、つまりスキップされる単語である冗長語を「透過単語」と呼ぶ。このモデルにおいては、それ自身、つまり冗長語は冗長語以外の単語（通常単語）の各々の間に等しい確率で出現するとして確率の計算が行われる。

【０００７】

しかしながら、この冗長語が実際に何ら情報をもっておらず、通常単語間に自由に出現するものか否かについて、英語ではその仮定を否定する報告がある。たとえば「Statistical Language Modeling for Speech Disfluencies (A. Stolcke, E. Shriberg, Proc. of ICASSP96)」では、冗長語に対しても通常のＮ－ｇｒａｍを適用した結果、冗長語に後続する単語の予測精度が、透過単語モデルより向上したことが記述されている。だが先の透過単語の説明で明らかなように、経験上、冗長語のもつ性質が通常単語と異なり、単純な順序列としてモデル化することが最適ではないことも知られている。

【０００８】

一方、現在一般に用いられている、ディクテーション用音声認識システムでは、異なる２つ以上の言語モデルを補間するという方法が用いられることが多い。これは本来ベースとなる汎用の言語モデルでは、コンピュータ、スポーツといった分野固有の文に対して十分対応できない場合、その分野固有のテキストから学習した特定分野言語モデルを汎用のそれと組み合わせる手法であり、以下のように確率計算が行われる。

$$Pr(w[n]|w[n-2],w[n-1])=\lambda P1(w[n]|w[n-2],w[n-1])+(1-\lambda)P2(w[n]|w[n-2],w[n-1])$$

ただし、P1は汎用言語モデルを示し、P2は特定分野言語モデルを示す。ここでλは補間係数であり、実験により最適な値に設定することとされている。

【０００９】

【発明が解決しようとする課題】

本願発明は、従来より認識率の高い音声認識装置及び音声認識方法を提供することを目的とする。

【００１０】

さらに、本願発明は、冗長語周辺部における単語予測の精度を向上させることを目的とする。

【００１１】

【課題を解決するための手段】

本願発明では、単語を冗長語とそれ以外の通常の単語にわけ、予測される単語、条件となる先行単語いずれにおいても、この２つを区別し、それぞれについて上述の補間法を冗長語を含む単語列に適用することによって冗長語周辺部における単語予測の精度を向上させる。

【００１２】

より具体的には、アナログ音声入力信号をデジタル信号に変換処理を行う音響処理手段と、音の特徴を学習した音響モデルを記憶した記憶手段と、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶手段と、前記デ

ジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する手段と、を有する音声認識装置を提供する。

【００１３】

また、アナログ入力手段と、前記アナログ音声をデジタル信号に変換処理する手段と、音の特徴を学習した音響モデルを記憶した記憶手段と、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶手段と、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する手段と、前記認識された結果を表示する表示装置とを有するコンピュータ・システムを提供する。

【００１４】

さらに、アナログ音声入力信号をデジタル信号に変換処理し、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶し、前記デジタル信号について音響モデルと前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する音声認識方法を提供する。

【００１５】

さらに、アナログ音声を入力し、前記アナログ音声をデジタル信号に変換処理し、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶し、前記デジタル信号について音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識し、前記認識された結果を表示する音声認識方法を提供する。

【００１６】

さらに、コンピュータ・プログラムを有するコンピュータ読みとり可能な記憶

媒体であって、前記記憶媒体は、音響モデルと、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶し、さらに前記コンピュータ・プログラムは、コンピュータに入力されたアナログ音声入力信号が変換されたデジタル信号について前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させるものである記憶媒体を提供する。

【００１７】

さらに、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶媒体を提供する。

【００１８】

さらに、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識をするための装置であって、認識の対象となる入力された語が通常単語かどうか判断する手段と、通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断する手段と、条件となる語が通常単語のみでなく冗長語も含むと判断された場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させる手段と、を有する音声認識装置を提供する。

【００１９】

さらに、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識をするための方法であって、認識の対象となる入力された語が通常単語かどうか判断するステップと、通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断するステップと、条件となる語が通常単語のみでなく冗長語も含むと判断さ

れた場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させるステップと、を有する音声認識方法を提供する。

【００２０】

さらに、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章について音声認識をするためのコンピュータ・プログラムを有するコンピュータ読みとり可能な記憶媒体であって、前記コンピュータ・プログラムは、コンピュータに認識の対象となる入力された語が通常単語かどうか判断する手順と、通常単語であると判断された場合、さらに入力された語を認識するために必要な条件となる語が通常単語のみからなるかどうかを判断する手順と、条件となる語が通常単語のみでなく冗長語も含むと判断された場合、冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識させる手順と、を実行させるものである記憶媒体を提供する。

【００２１】

さらに、アナログ音声入力信号をデジタル信号に変換処理を行う音響処理装置と、音の特徴を学習した音響モデルを記憶した第１の記憶装置と、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した第２の記憶装置と、前記音響処理装置及び前記第１及び第２の記憶装置に接続され、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する装置と、を有する音声認識装置を提供する。

【００２２】

さらに、アナログ音声の入力装置と、前記入力装置に接続され、前記アナログ音声をデジタル信号に変換処理する変換装置と、音の特徴を学習した音響モデル

を記憶した第１の記憶装置と、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した第２の記憶装置と、前記変換装置及び前記第１及び第２の記憶装置に接続され、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する装置と、前記認識された結果を表示する表示装置とを有するコンピュータ・システムを提供する。

【００２３】

【発明の実施の形態】

図１は、本願発明の構成を示すブロック図である。ブロック１０１において生成された文章（すなわち真の文章）Ｗは、Ｓとして発話される（１０２）。一般にこの文章生成及び発話は発話者によってなされる。発話されたＳは、文章Ｗだけでなく、「アノー」「エート」等の冗長語を含む音である。この入力された音声であるＳは、音声認識手段１１０中の音響処理部１１１によって信号Ｘに変換されて記憶される。この変換された信号Ｘは、言語復号部１１２において、音の特徴を学習した音響モデル１１３と、後述する学習により予め作成された言語モデルについての辞書１１４を用いて、真の文章だけでなく冗長語を含むものから必要な言語を抽出して認識結果Ｗ’とする。このような一連の動作を音にエンコードされたデータから必要なデータをデコード（復号）するともいう。そして、認識された結果の文章を表示する（１２０）。

【００２４】

次に、本願発明の実施される装置の典型的なシステムの一例について図２に示す。発話者が発話した音声はマイク２１０からアナログ信号として入力され、コンピュータ装置２２０のサウンドカード２２１によりデジタル信号に変換処理され、メモリ２２２に記憶される。なお、このような機能を奏するものであれば、ハードウェアとして実現されていても、ソフトウェアとして実現されていてもいずれでも良い。さらに、音響モデル及び後述する学習により作成された言語モデルを含む辞書もメモリに記憶されている。これらの変換され記憶された信号及び

辞書からＣＰＵ２２３は言語の復号を行い、認識された結果を表示装置２３０に表示する。なお、マイクはコンピュータ装置や表示装置と一体化されていることもある。また、表示装置による結果の表示はＣＲＴや液晶などディスプレイだけでなく、印刷装置により紙に印刷されるような場合もある。

【００２５】

図１のブロック図と図２のシステムとの対応を考えると、一例として、マイク、サウンドカード及びメモリにより音響処理部の前段部が実現され、また音響モデルと辞書（言語モデル）はメモリ上に記憶され、音響処理部の後段部と言語復号はＣＰＵを用いて行われ（音響処理部の処理は単なるデジタル信号への変換だけでなく、特徴Ｘの抽出などのためにＣＰＵが必要となる）、文章の表示は表示装置において行われる。ただし、これらの関係は固定的なものではない。例えば変換された信号を記憶するメモリと辞書を有するメモリは物理的に異なるものとすることもできる。ただし、このような場合もそれらを一体としてメモリとして考えることも可能である。

【００２６】

上述の通り、本発明は単語を冗長語とそれ以外の通常の単語（通常単語）にわけ、予測される単語、条件となる先行単語いずれにおいても、この２つを区別し、さらにこの補間法を冗長語を含む単語列に適用することによって、冗長語周辺部における単語予測の精度を向上させようとするものであるが、その具体的な内容について以下により詳細に述べる。

【００２７】

冗長語のもつ性質の特殊性は、その情報が後続単語の予測に寄与する程度が不明確な点にある。すなわち、冗長語を無視して、それ以前の通常単語から予測する方がよいというのが従来技術で述べた透過単語モデルの考え方である。これに対して、通常のＮ－ｇｒａｍモデルは、後続単語の予測に最も役にたつのは、それに隣接する単語であるという考え方に基づいている。そこで、この２つの方法で複数の言語モデルを作成し、それらのモデルを補間して予測を行う。具体的には以下の過程をへて確率の学習・計算を行う。以下簡単のためすべてＮ＝３（３－ｇｒａｍ）とする。

【００２８】

まず、予め準備されたテキストデータに基づいて、学習により図３に示すような辞書３００を生成する。具体的には、以下のようにして２つのモデルに基づく辞書が生成される。なお、いずれの場合においても、冗長語が連続する場合には、たとえば連続する冗長語列を１つの冗長語に置き換えて学習すればよい。

【００２９】

１．各通常単語について、冗長語を除去した通常単語のみからなる学習テキストデータを用いて３－ｇｒａｍの確率を学習する。つまり上述の透過単語モデルの考え方による言語モデルである。これをモデルＵ（３１０）とする。

【００３０】

２．冗長語を含むテキストについて学習を行う。この場合、さらに以下の２つの場合がある。ここでwfilは冗長語を表す。

（１）予測の対象となる語が冗長語wfilである場合の３－ｇｒａｍ確率、すなわちP(wfil|w[n-2],w[n-1])を学習する。ここで、例えば条件のうちw[n-1]が通常単語、w[n-2]が冗長語というような可能性があるが、その場合にはw[n-2]をとばし、w[n-3]を条件部に用いP(wfil|w[n-1],w[n-3])とする。つまり、この場合条件に冗長語は含まないようにする。

（２）予測の対象となる語が通常単語であり、その直前が冗長語である場合、その冗長語のみを条件とする２－ｇｒａｍ確率P(w[n]|wfil)を学習する。つまり、通常単語の直前が冗長語である場合の確率である。

以上のように、条件部、予測対象のそれぞれにおいて冗長語と通常単語を分けた確率を学習することが本学習の基本である。この２．（１）、（２）をあわせてモデルＤ（３２０）とする。

【００３１】

このように学習により生成された辞書を用いて、図４に示すようなフローチャートに従って認識のための確率計算を行う。以下、かかる図４について説明する。

【００３２】

まず、音響処理部によって変換された音声信号について音響モデルを用いた計

算の結果に基づいて認識候補として単語を選択する（４００）。ここで、例えば認識候補としての単語は数百個程度に絞られる。次に、候補となる単語が通常単語であるか、冗長語であるかが判断される（４１０）。本発明では、対象単語が冗長語であるか通常単語であるかによって異なる確率計算を行うからである。

【００３３】

候補の単語が通常単語w[n]である場合、条件部w[n-2]w[n-1]も通常単語のみからなるかどうかが判断され（４２０）、条件部w[n-2]w[n-1]も通常単語のみからなる場合は、モデルUのP(w[n]|w[n-2],w[n-1])からw[n]の予測、つまり確率計算を行う（４３０）。

【００３４】

認識対象の単語が通常単語w[n]であるが、条件部に冗長語が存在すると判断された場合は、モデルUとモデルDの両方の辞書を用いて確率計算が行われる（４４０）。

【００３５】

このブロック４４０について、本実施例についてより詳細に説明すれば、認識対象の単語が通常単語w[n]であるが、条件部に冗長語が存在するかどうかが判断され（５１０）、直前の単語w[n-1]が冗長語の場合は、それをとばして最も近接した通常単語まで遡りそれを条件としたモデルUの確率と、直前が冗長語であったという条件のモデルDの確率を補間してw[n]の確率計算を行う（５２０）。つまり当該確率Prは以下の式により求められる。

$Pr=\lambda PU(w[n]|w[n-2],w[n-1])+(1-\lambda)PD(w[n]|wfil)$

ここで、PU：モデルUによる確率、PD：モデルDによる確率を示す。また、補間係数λは予め実験により最適な値に決定する。例えば、補間係数の決定は、実験において補間係数λを０から１まで０．１刻みで変化させ、冗長語を含むモデル文章について最も認識率が高くなるような値を採用する。

【００３６】

認識対象の単語が冗長語w[n]である場合、条件部w[n-2],w[n-1]に冗長語が存在するにはそれをとばして（５３０）、最も近接した通常単語w[n-i]，w[n-j]まで遡り、それを条件部とするモデルD、PD(w[n]|w[n-i],w[n-j])により確率計算

を行う（５４０）。

【００３７】

以上の結果に基づいて、言語モデルによる予測される語の確率を求める（４６０）。この場合、最も確率の高い語を認識語として表示させるようにしても良いし、あるいはこの予測結果からさらに候補語を百語程度に絞り込み、再度音響モデルによる確率計算を詳細に行い認識結果を算出しても良い。

【００３８】

このように、本発明においては、確率計算において、予測対象、条件のいずれにおいても、冗長語である場合と、そうではない場合を分離し、それらを別々に学習しておくこと、そして確率計算時においては、その２つのモデルを補間して通常単語・冗長語の影響がより適した割合で考慮されることになる。

【００３９】

なお、本発明においては、補間係数λを適切な値に設定することが、その効果に大きく影響する。その値に影響を与える要素としては、不要語の出現率、学習コーパスの量など多くのものがあり、理論的考察が困難なため、実験により、言語モデルがどの程度有効に働いているかという値を求め、それを基準として決定することが多い。

【００４０】

言語モデルの有効性は一般にパープレキシティという統計量が用いられる。その定義の詳細はたとえば、「音声・音情報のディジタル信号処理」（鹿野他著、昭晃堂、１９９７年）に記述があるが、直感的には全認識対象語彙（たとえば６万語）が言語モデルを使用することにより、何単語程度の対象語彙と等価にまで減少したかを意味し、より小さい値の方がよい。

【００４１】

たとえばテレビの講演を書き起こした約100万単語からなるコーパスの場合、λは0.2が最適であった。そこでパープレキシティを求めた結果、透過単語モデルは225.0であるのに対して、本発明によるモデルでははは195.1であり、約13%の改善であることがわかった。当業者であれば理解されるところであるが、この分野における改良案には不要語に限らず多くのものがあるが、その中でこの値は大

きいものである。

【００４２】

以上の例の他、冗長語予測においても条件部において、直前単語が冗長語、すなわち冗長語が連続する場合に、その条件付き確率と補間することなど、さまざまな組み合わせが考えられる。

【００４３】

例えば、上述の例では、モデルＤについて、対象語の直前が冗長語の場合についてのみ学習を行わせたが、例えばその対象語の２語前が冗長語の場合（３－ｇｒａｍモデル）等の確率もさらに加味して補間する方法もある。

【００４４】

さらに、本発明においては前述のように、音響処理部によって変換された音声信号について、まず先に音響モデルを用いた計算の結果に基づいて認識候補として単語を選択してある程度絞り込んだ上でそれらに言語モデルを適用して確率を求めて総合判定を行い認識の最終結果を得るが（図６（ａ））、逆にまず先に認識された語の履歴に基づいて言語モデルを適用して候補となる語をある程度絞り込んだ上でそれらに音響モデルを適用して認識を行う方法も考えられる（図６（ｂ））。

【００４５】

【発明の効果】

本願発明により、従来より認識率の高い音声認識装置及び音声認識方法を提供するが可能となり、さらに、冗長語周辺部における単語予測の精度を向上させることが可能となる。

【図面の簡単な説明】

【図１】

本発明の構成を示すブロック図である。

【図２】

本発明の実施されるコンピュータ・システムの一例を示す図である。

【図３】

本発明に用いられる辞書についての図である。

【図４】

本発明の処理の流れを示すフローチャートである。

【図５】

本発明の処理の流れを示すフローチャートである。

【図６】

音声認識処理の流れを示すフローチャートである。

【符号の説明】

１１０　音声認識手段

２１０　マイク

２２０　コンピュータ装置

２２１　サウンドカード

２２２　メモリ

２２３　ＣＰＵ

２３０　表示装置

【書類名】　図面

【図１】

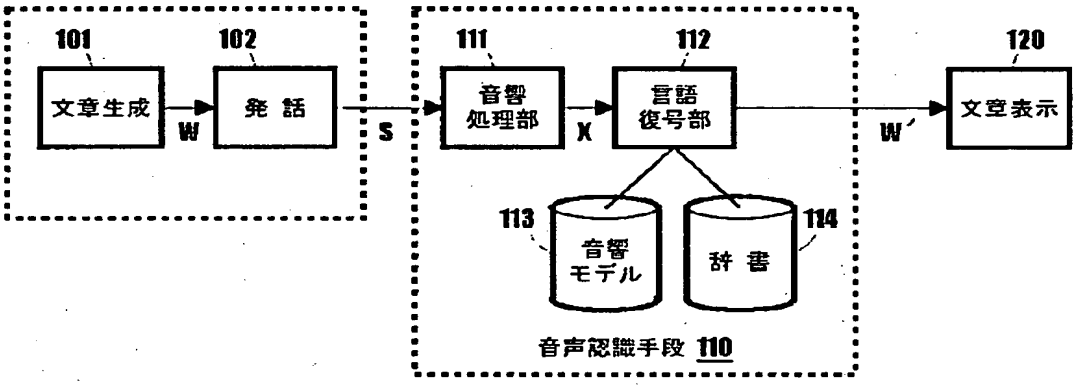
101
文章生成
W
102
発 話
S
111
音響
処理部
X
112
言語
復号部
W'
120
文章表示
113
音響
モデル
114
辞 書
音声認識手段 110

【図２】

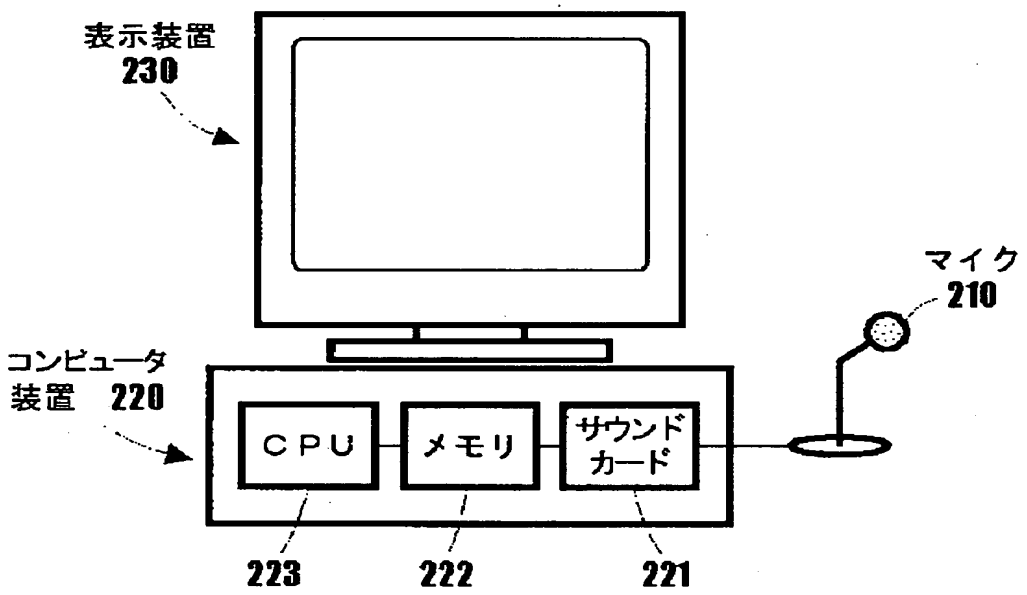
表示装置
230
マイク
210
コンピュータ
装置 220
CPU
メモリ
サウンド
カード
223
222
221

【図３】

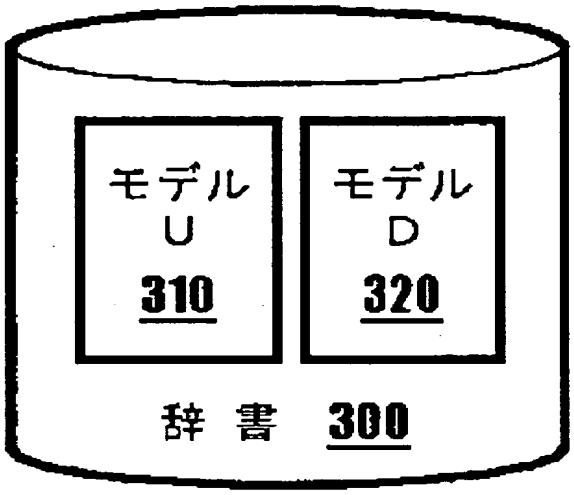

【図４】

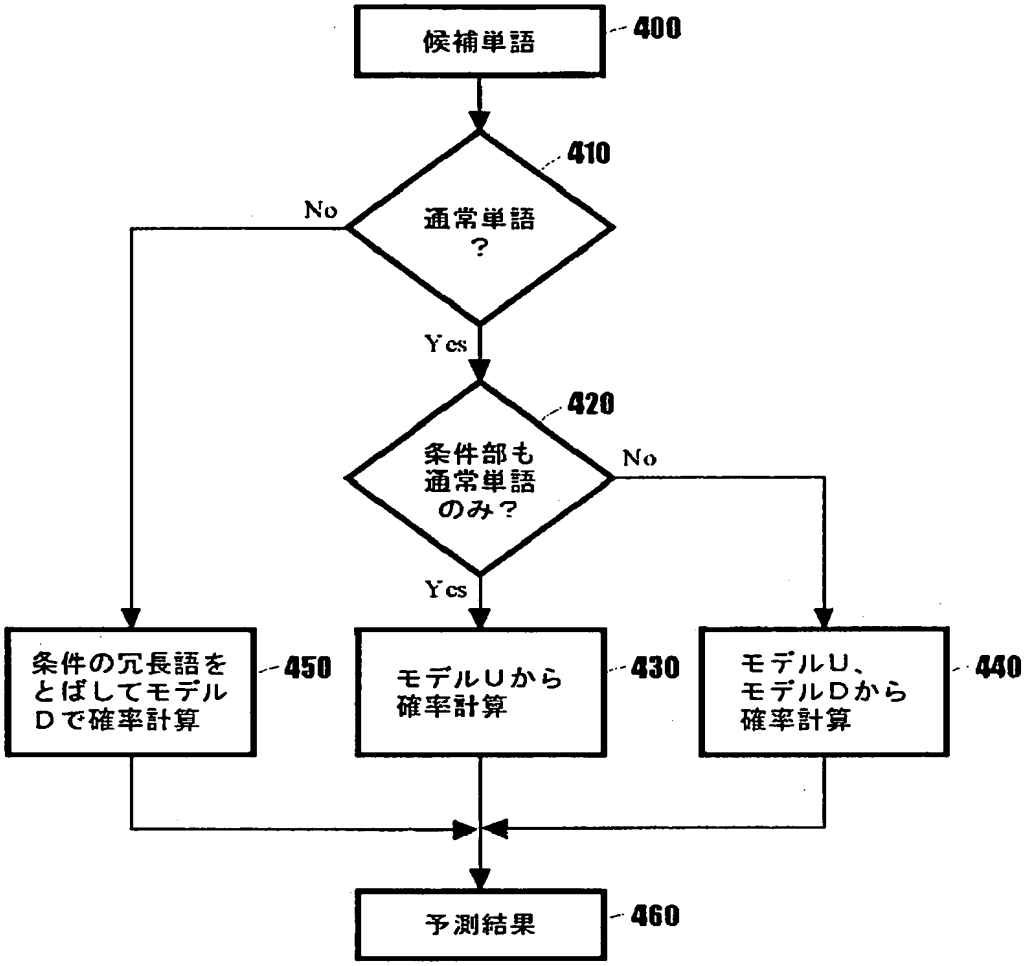
候補単語
400
410
通常単語
？
No
Yes
420
条件部も
通常単語
のみ？
No
Yes
条件の冗長語を
とばしてモデル
Ｄで確率計算
450
モデルＵから
確率計算
430
モデルＵ、
モデルＤから
確率計算
440
予測結果
460

【図５】

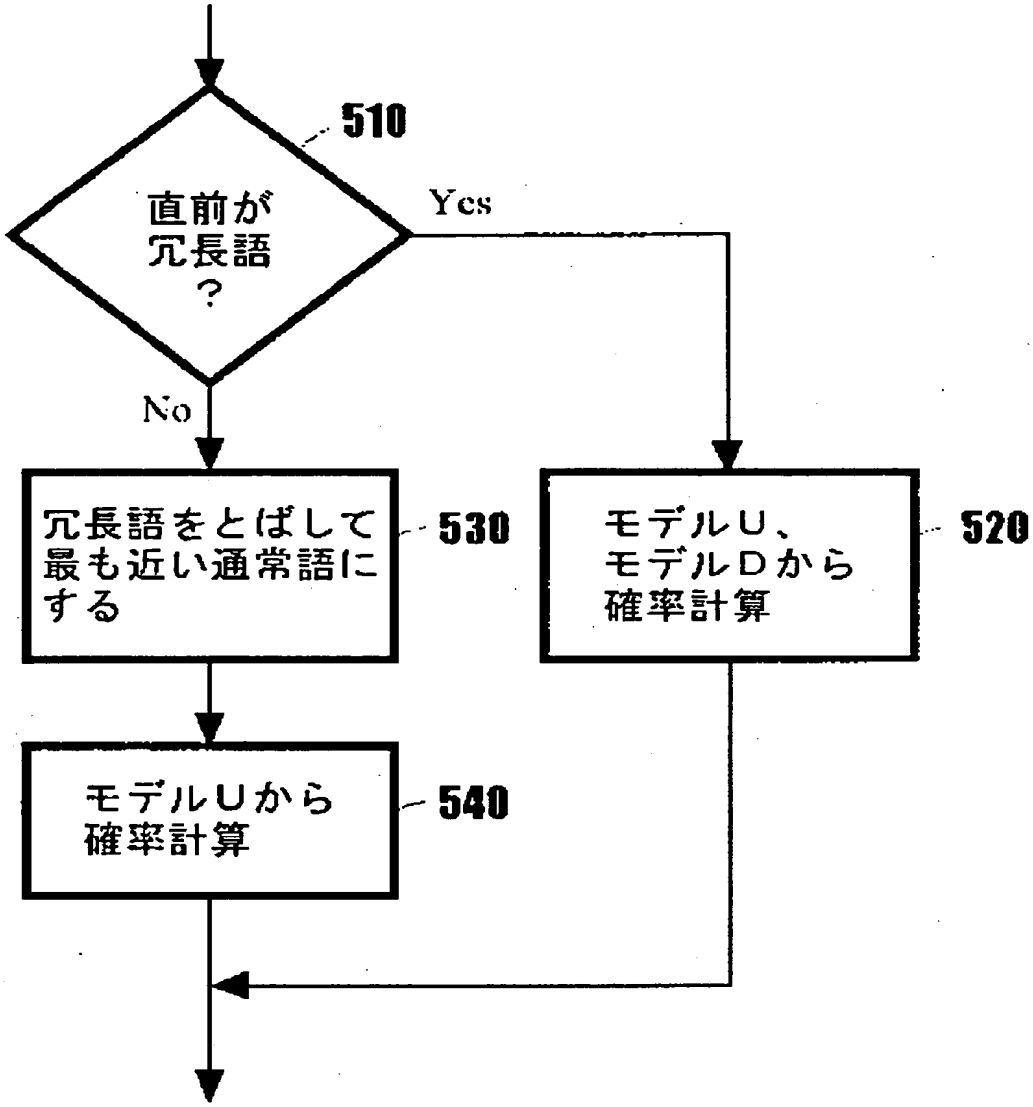
510
直前が
冗長語
？
Yes
No
冗長語をとばして
最も近い通常語に
する
530
モデルU、
モデルDから
確率計算
520
モデルUから
確率計算
540

【図６】

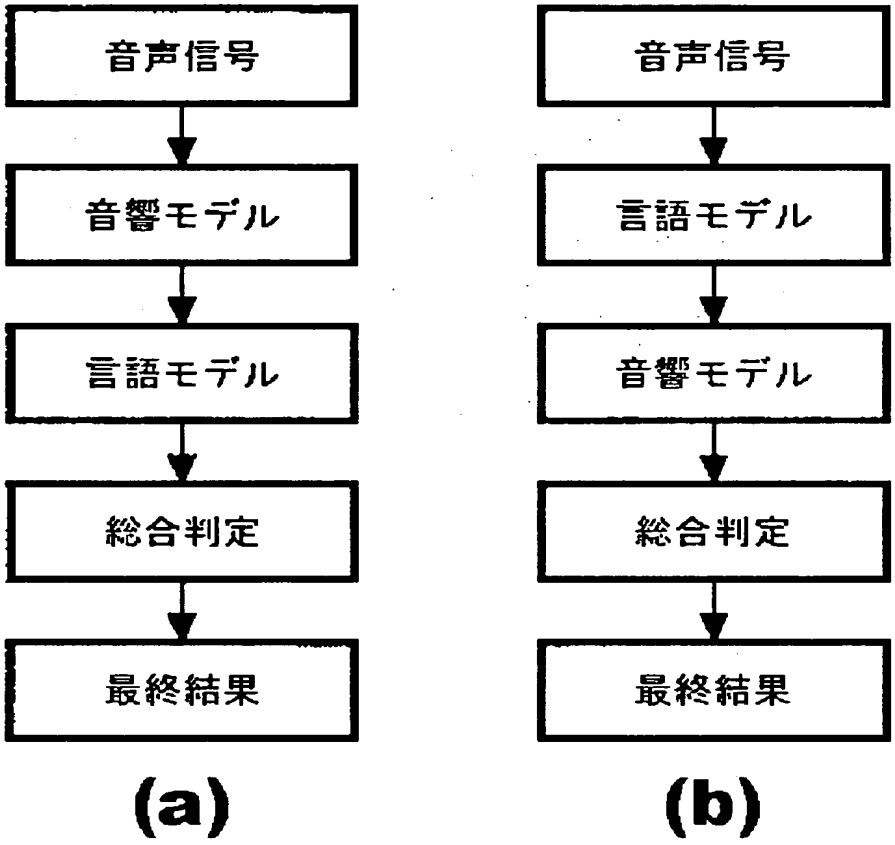

【書類名】要約書

【要約】

【課題】

従来より認識率の高い音声認識装置及び方法を提供すること。

【解決手段】

本願発明では、単語を冗長語とそれ以外の通常の単語にわけ、予測される単語、条件となる先行単語いずれにおいても、この２つを区別して予測を行うことにより冗長語周辺部における単語予測の精度を向上させる。そのために、アナログ音声入力信号をデジタル信号に変換処理を行う音響処理手段と、音の特徴を学習した音響モデルを記憶した記憶手段と、予め冗長語と冗長語以外の通常の単語（通常単語）とを含む文章に基づいて学習した第１の言語モデルと、冗長語を無視して通常単語のみの文章に基づいて学習した第２の言語モデルと、の両方の言語モデルを有する辞書を記憶した記憶手段と、前記デジタル信号について前記音響モデル及び前記辞書を用いて確率を計算して最も確率の高い語を入力された音声として認識する手段と、を有する音声認識装置を提供する。

【選択図】図１

出証特２０００－３０１４４７０

認定・付加情報

特許出願の番号	平成１１年　特許願　第３７０４１３号
受付番号	５９９０１２７３２６８
書類名	特許願
担当官	第七担当上席　　００９６
作成日	平成１２年　１月　４日

＜認定情報・付加情報＞

【提出日】　平成11年12月27日

次頁無

出　願　人　履　歴　情　報

識別番号　　〔３９０００９５３１〕

１．変更年月日　　１９９０年１０月２４日
［変更理由］　新規登録
住　所　　アメリカ合衆国１０５０４、ニューヨーク州　アーモンク　（番地なし）
氏　名　　インターナショナル・ビジネス・マシーンズ・コーポレイション